

WEEKLY REPORT

张建伟

September 9, 2018

1 上周工作

AIIA 比赛 — 肝脏肿瘤分割

复赛于周六已经结束, 我们的队伍由陈峰主任完成了 PPT 的展示和相关问题的答辩. 刘云鹏老师, 王虎峰 (昆捷员工, 负责 Li-RADs 技术实现) 和我从旁准备应对技术方面的问题, 由于专家评审问的都是医学相关的问题, 所以最终全部问题都由陈峰主任回答. 目前在等待复赛结果 (大约是 50 进 10).

目前的工作

1. 完成了 2D DenseUNet 的训练和测试, 同时分割肝脏和肿瘤, 经过一定的调参, 在测试集上的分割精度如下:
 - Liver on test set: 0.946
 - Tumor on test set: 0.669
 - Liver on total set: 0.958
 - Tumor on total set: 0.822
2. 对 MGH 的数据集进行了进一步检查, 筛选出 115 组 (原始的 159 组) 三期 CT 来实现三期数据的训练. 剔除的 CT 是由于配准严重变形而干扰到肿瘤识别的情况. 划分训练/验证集为 92/23, 以三期数据作为三通道输入 CDNN 网络训练, 得到分割结果如下:
 - Tumor on test set: 0.654
 - Tumor on test set: 0.816

可以看出并没有想象中那样的效果提升. 本周四在昆捷和蔡老师的讨论中分析可能是直接输入三期原始数据网络难以综合三期数据的特征, 所以可能需要人为地从三期数据中提取**差别性特征**如: APHE, "Washout", Enhancing "capsule" 等.

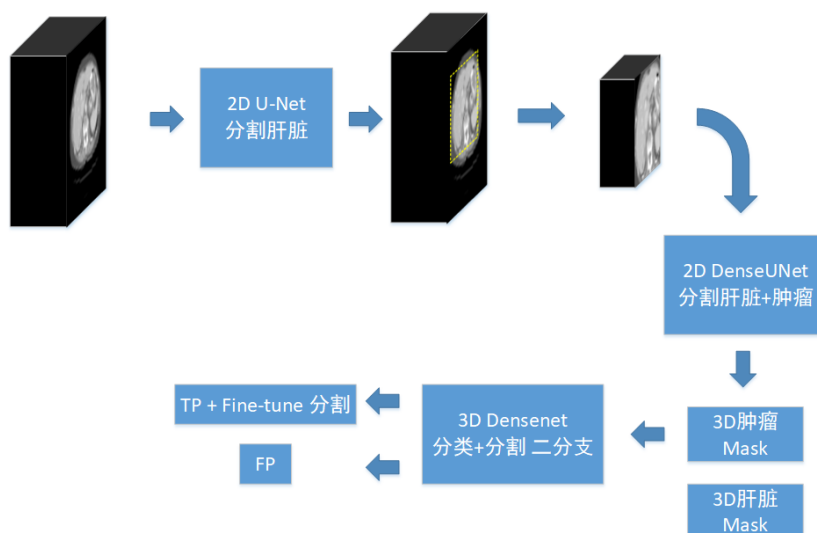
3. 3D DenseUNet 和 H-DenseUNet 代码部分基本完成

工作时长

周一至周五每天 12 小时左右, 周六上午去参加 AIIA 比赛, 下午和晚上 7 小时, 周日 8 小时.

2 一些想法

- 目前考虑的稍完整些的肝脏肿瘤分割的流程如图 其中 2D U-Net 分割



肝脏, 2D DenseUNet 分割肝脏 + 肿瘤这两个网络基本调参结束. 最后的 3D Densenet 以及分类 + 分割分支是新添加的部分. 考虑到目前肿瘤的检测精度最高也仅有 0.538(检测精度高的分割精度和召回率不一定高), 所以在最后增加该网络是为了从前一步 2D DenseUNet 中分割出的肿瘤中剔除假阳性肿瘤, 同时提高真阳性的分割精度. 由于前一步 2D DenseUNet 中已经分割出了目标, 所以最后仅需要一个小

型的 3D 网络处理包含目标的 patch 即可. 考虑到肝肿瘤的大小差异巨大 (从几 mm 到上百 mm 不等), 多尺度网络/多尺度输入是必要的.

3 下周工作

- 对当前最好的模型的肿瘤分割结果进行全面的分析, 包括: 所有肿瘤的分割精度, 准确率, 召回率; 大肿瘤 ($>50\text{mm}$) 和小肿瘤 ($<20\text{mm}$) 的分割精度, 准确率, 召回率; 未分割出的肿瘤有什么特征, 分割不准确的肿瘤有什么特征, 误识别为肿瘤的正常组织有什么特征等
- 学习肝脏三期数据的差别性特征, 并以这些特征作为神经网络的输入训练. 这样做的原因是医生在从三期肝脏数据中识别肿瘤时往往也是从这几方面的特征中判断肿瘤的.
- 在 2D DenseUNet 的基础上训练 H-DenseUNet 并进行初步测试
- 完成目前想到的 3D 分类 + 分割网络结构的构思和代码实现.

4 论文阅读

4.1 Learning and Incorporating Shape Models for Semantic Segmentation

本文针对当前医学图像分割任务中缺乏形状先验的问题, 提出了形状模型网络如图 3. 其中图 3(a) 是医学图像分割任务中常用的 U-Net, 而图 3(b) 是本文提出的形状正则化网络, 该网络是 Encoder-Decoder 结构, 不包含 U-Net 中的 long skip connection 结构. 该网络输入如图 4(a) 和 (b) 中上面一行的几类残缺的分割, 然后由形状正则化网络学习其特征并预测出下面一行那样的完整结构. 形状正则化网络是预训练后直接插在 U-Net 后使用的. 作者实验的数据集为肾脏超声图像训练, 包括 100 例训练图像用于训练和 131 例图像用于测试. 实验证明使用形状正则化网络比不使用以 Dice 系数作为评估标准能够提升 5-6 个百分点.

4.2 机器学习 – 第七章: 贝叶斯分类器

贝叶斯决策论是概率框架下实施决策的基本方法. 通过寻找判定准则 h 来极小化条件风险 $R(h(x)|x)$:

$$h^*(x) = \operatorname{argmin}_{c \in Y} R(c|x),$$




Fig. 3: Network architectures

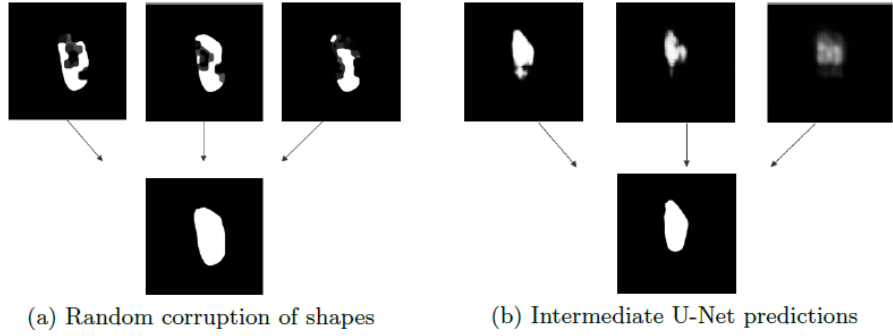


Fig. 4: Data augmentation strategies for shape CAE training


那么 h^* 即为贝叶斯最优分类器. 由于后验概率难以获得, 所以通常使用贝叶斯公式把后验概率的计算转化为先验概率和样本对于类别的类条件概率:

$$P(c|x) = \frac{P(c)P(x|c)}{P(x)}.$$

类条件概率是 $P(x|c)$ 是所有属性的联合概率, 所以如果我们假设所有属性相互独立, 那么就可以容易的计算出这个类条件概率, 此时就得到了**朴素贝叶斯分类器**; 如果对属性的独立性假设放松一些, 那么就得到了**半朴素贝叶斯分类器**. 独依赖估计是假设所有的属性都依赖于一个父属性, 贝叶斯网是把属性间的依赖关系以有向无环图的形式来表示.

4.3 Multi-level Contextual 3D CNNs for False Positive Reduction in Pulmonary Nodule Detection

本文针对肺结节假阳性筛查问题提出了多尺度的思想. 由于肺结节的大小从 3mm 到 30mm 不等, 变化较大, 所以采用单个网络识别结节存在信息利用不充分或信息不足的情况. 如图所示, 作者统计了不同大小肺结节的占



比, 设计了三种尺度 (20x20x6, 30x30x10, 40x40x26) 的 3D 卷积网络分别对候选结节做分类, 并在最终使用加权平均的方式将三个网络的结果按照公式

$$\mathbb{P}_{\text{fusion}}(\hat{\mathcal{Y}}_j = c | \mathcal{I}_j) = \sum_{\phi \in \{1,2,3\}} \gamma_{\phi} \mathbb{P}_{\phi}(\hat{\mathcal{Y}}_j = c | \mathcal{I}_j; \theta_{\phi})$$

融合三个网络的预测结果.

本文的创新点在于作者考虑到了标志肺结节的信息不仅仅存在于结节本身, 还存在于其周围环境. 当网络的可视环境太大, 会导致冗余信息过多; 当网络的可视环境太小, 又会导致肺结节的信息丢失. 然而决定肺结节的环境信息很难做一个量化, 所以用多尺度的图像来训练不同的网络既能让某一个对于当前结节最合适的网络学习到其特征, 又能够兼顾到不同大小的结节.

4.4 Recent Advances in Deep Learning: An Overview

本文是 2017 年的一篇深度学习综述文章. 文中对目前的深度学习方法做了较为全面的总结, 主要包括:

- 深度网络结构: AlexNet, VGG, ResNet, R-CNN 系列, RNN 系列, LSTM 系列
- 深度生成模型: Boltzmann Machines, 受限 Boltzmann Machines, 深度信念网络, 生成对抗网络, 循环 SVM
- 训练和优化技巧: Dropout, Deep Residual Learning, Batch Normalization, Distillation(用于压缩模型)

- 深度学习框架: Tensorflow, PyTorch, Caffe
- 深度学习的应用等

4.5 统计学习方法 — 第 8 章 提升方法

提升方法中最具代表性的是 AdaBoost 算法. 其核心思想是针对不同的训练数据分布训练多个弱分类器, 构成一个强分类器. 对于前一个弱分类器分类错误的样本, 在下一个弱分类器中增大其权重, 同时减弱分类正确样本的权重, 从而使难样本得到更多的关注. 最终 AdaBoost 采用加权表决的方式综合多个弱分类器得到一个强分类器, 权重由每个弱分类器的误差率决定, 误差率大的权重小, 误差率小的权重大.

此外, AdaBoost 算法还可以被解释为加法模型, 损失函数为指数函数, 学习算法为向前分步算法, 并且有定理保证了该解释的正确性. 提升方法中最为有名的是提升树, 以决策树作为基本分类器的提升方法.